

## PENINGKATAN BACKWARD ELIMINATION DENGAN WINDOWED MOMENTUM UNTUK PREDIKSI KONTRASEPSI

**Evy Priyanti**

Program Studi Komputerisasi Akuntansi  
Akademik Manajemen Informatika dan Komputer Bina Sarana Informatika  
AMIK BSI JAKARTA  
Jl. Rs Fatmawati No 24, Jakarta Selatan  
evy.evp@bsi.ac.id

### ABSTRACT

*Rapid population growth rate that can influence government policies on various aspects of life. It is necessary for the proper way to reduce the rate of population growth and create a safer contraceptive choice. Windowed momentum is a technique to improve the performance in backpropagation learning. But to ensure the accuracy of the momentum needed windowed performance computing methods such as neural networks to solve problems with the accuracy of data and not linear. Neural Network Optimization tested weeks to produce the best accuracy rate, applying Neural Network-based Backward Elimination aims to raise the accuracy produced by Neural Network. Experiments were performed to obtain the optimal architecture and generate increased accuracy. The results of the research is a confusion matrix to prove the accuracy of Neural Network before Backward Elimination is optimized by 54.64% and 57.03% after optimize. This proves estimate windowed momentum trials using neural network-based method Backward Elimination more accurate than the individual methods of neural network.*

**Keyword:** Contraception, Data Mining, Neural Network, Windowed Momentum

### I. PENDAHULUAN

Laju pertumbuhan yang semakin meningkat akan mempengaruhi beberapa faktor diantaranya faktor sosial politik yang dapat membawa perubahan sistem pemerintahan yang cukup besar (Bandyopadhyay & Chattopadhyay, 2008).

Kontrasepsi merupakan salah satu faktor penentu kesuburan dan prediktor yang paling penting dari transisi fertilitas. Pemilihan metode kontrasepsi juga dipengaruhi oleh sejumlah faktor demografi yang saling bergantung diantaranya faktor budaya, ekonomi, dan sosial yang berarti bahwa pendekatan multidimensional perlu diadopsi untuk menganalisis pola penggunaan kontrasepsi. Setiap analisis berdasarkan indikator tunggal tidak mungkin untuk menangkap semua dimensi dari pemilihan metode kontrasepsi (Chaurasia, 2014).

Neural Network (NN) adalah teknik peramalan yang paling umum digunakan, karena NN bisa cepat dan akurat, banyak peneliti menggunakan NN untuk memecahkan masalah peramalan (Liao, 2007). Neural Network mempunyai kelebihan yaitu jaringan syaraf mampu menyelesaikan problem nonlinear, mempunyai toleransi yang cukup

tinggi terhadap data yang mengandung noise dan mampu menangkap hubungan yang sangat kompleks antara variabel-variabel prediktor dan outputnya, namun Neural Network juga mempunyai kekurangan yaitu adanya overgeneralisasi, dimana penggunaan jumlah data yang banyak, Neural Network melakukan dengan sangat baik untuk data pelatihan, tetapi gagal untuk melakukan dengan baik untuk data validasi. Masalah ini mungkin disebabkan oleh jumlah neuron yang berlebihan, durasi pelatihan yang berlebihan, atau alasan lain yang serupa. Generalisasi yang berlebihan terjadi ketika Neural Network, dengan algoritma pelatihan, mulai meniru fungsi yang sangat kompleks di tempat yang sederhana (Shukla, Tiwari & Kala, 2010).

Feature Selection adalah masalah yang berkaitan erat dengan pengurangan dimensi. Tujuan Feature Selection adalah untuk mengidentifikasi fitur dalam kumpulan data yang sama pentingnya, dan membuang semua fitur lain seperti informasi yang tidak relevan dan berlebihan. Karena feature selection mengurangi dimensi dari data, sehingga memungkinkan operasi yang lebih efektif & algoritma data mining yang cepat


(yaitu data algoritma mining dapat dioperasikan lebih cepat dan lebih efektif dengan menggunakan feature selection) (Maimon & Rokach, 2010). Feature selection adalah salah satu faktor yang paling penting yang dapat mempengaruhi tingkat akurasi klasifikasi (Liu et al., 2011). Penelitian menggunakan feature selection yang pernah dilakukan oleh Yuanning Liu, Gang Wang, Huiling Chen, Hao Dong, Xiaodong Zhu & Sujing Wang tahun 2011, dimana hasil penilitan menunjukkan bahwa penggunaan metode Improved feature selection (IFS) menunjukkan hasil yang signifikan lebih baik daripada tiga metode lain yang digunakan dalam penelitian tersebut (GA, SVM, PSO) dalam hal akurasi prediksi dengan subset feature yang lebih kecil.

Windowed momentum dapat meningkatkan waktu pengklasifikasian dari hasil feature selection sehingga didapat momentum yang lebih maksimal (Istook & Martinez, 2002).

## II. LANDASAN TEORI

Data mining atau disebut juga Knowledge Discovery in Database (KDD) adalah ekstraksi pola secara otomatis mewakili pengetahuan yang disimpan atau ditangkap secara tersembunyi di dalam sebuah database besar (Han & Kamber, 2007).

Berdasarkan tugasnya, data mining dikelompokkan menjadi (Larose, 2005): 1). Klasifikasi, 2). Estimasi, 3). Prediksi, 4). Clustering, 5). Asosiasi. Salah satu algoritma yang dipakai dalam proses peramalan adalah Neural network yang merupakan satu set unit input/output yang terhubung dimana tiap relasinya memiliki bobot (Han & Kamber, 2007:24). Bobot relasi dalam jaringan dimodifikasi untuk meminimalkan nilai Mean Square Error (MSE) antara nilai prediksi dari jaringan syaraf tersebut dilakukan dalam arah mundur, dari output layer hingga layer pertama dari hidden layer sehingga metode ini disebut backpropagation (Han & Kamber, 2007).



Sumber : (Han & Kamber, 2007)

**Gambar 1. Arsitektur Jaringan Backpropagation**

Peningkatan akurasi dan performa yang ada didalam Neural network dapat dilakukan dengan pengurangan fitur yang tidak relevan (Maimon & Rokach, 2010). Feature selection yang digunakan dengan metode wrapper dalam proses mundur atau Backward elimination dan akan diuji dengan Windowed momentum. Setelah dilakukan pengujian akan dianalisa dan dievaluasi dengan menggunakan Confusion matrix.

## III. Metode Penelitian

Dataset yang digunakan oleh peneliti diperoleh dari UCI Machine Learning Repository yang dibuat oleh Tjen-Sien Lim pada 7 Juni 1997. Survei dataset dari Indonesia berdasarkan pemilihan kontrasepsi yang dipilih dengan total 1473 data dan atribut berjumlah 10 atribut yang terdiri dari : *Wife`s age, wife`s education, husband`s education, number of children ever born, wife`s religion, wife`s now working?, husband`s occupation, standart-of-living index, media exposure, contraceptive method used (class attribute)*.

Dataset ini akan dilatih dan diuji dengan Backpropagation. Masalah utama yang ada pada Backpropagation adalah lamanya iterasi yang harus dilakukan. Backpropagation tidak dapat memberikan kepastian tentang seberapa epoch yang harus dilakukan untuk mencapai kondisi yang diinginkan, oleh karena itu parameter-parameter jaringan dibuat sehingga dihasilkan jumlah iterasi yang relatif lebih sedikit.

Salah satu parameter yang paling berpengaruh adalah penentuan bobot yang ada didalam jaringan. Bobot yang menghasilkan nilai turunan aktivasi kecil sedapat mungkin dihindari karena akan menyebabkan perubahan bobot menjadi sangat kecil, demikian pula dengan nilai bobot awal yang terlalu besar karena akan menyebabkan nilai subset menjadi sangat kecil juga. Oleh karena itu dalam standar Backpropagation bobot dan


bias diisi dengan bilangan acak kecil. Jika ditemukan subset terbaik maka itulah adalah subset terbaik saat ini. Perulangan evaluasi akan berakhir sampai ditemukan subset terbaik dari hasil sebelumnya (Maimon & Rokach, 2010).

Momentum adalah parameter yang digunakan dalam jaringan yang merupakan perubahan bobot yang didasarkan atas arah gradien pola terakhir dan pola sebelumnya. Penambahan momentum dimaksudkan untuk menghindari perubahan bobot yang mencolok akibat adanya data yang sangat berbeda dengan yang lain (*outlier*). Apabila beberapa data terakhir yang diberikan memiliki pola serupa, maka perubahan bobot dilakukan secara cepat. Namun, apabila data terakhir yang dimasukkan memiliki pola yang berbeda dengan pola sebelumnya, maka perubahan dilakukan secara lambat (Siang, 2009). Windowed momentum dapat menentukan seberapa banyak pengaruh momentum yang harus dimiliki (Istook & Martinez, 2002).

Parameter yang berpengaruh selanjutnya adalah penentuan Hidden layer. Pada dasarnya Backpropagation dengan satu Hidden layer sudah cukup untuk mampu mengenali sembarang pasangan antara input dan target. Akan tetapi, penambahan jumlah layer tersembunyi kadangkala membuat pelatihan lebih mudah (Siang, 2009).

Parameter-parameter yang ada akan diukur seberapa tingkat akurasi dalam prediksi pemilihan metode kontrasepsi. Beberapa metode untuk mengukur performa dari hasil suatu prediksi dalam bentuk perhitungan kesalahan. Perhitungan kesalahan merupakan pengukuran bagaimana jaringan dapat belajar dengan baik sehingga jika dibandingkan dengan pola yang baru akan mudah dikenali. Kesalahan pada keluaran jaringan merupakan selisih antara keluaran sebenarnya dan target atau disebut metode pembelajaran *Supervised learning* (Maimon & Rokach, 2010).

Evaluasi terhadap model yang terbentuk akan dilakukan dengan pengukuran akurasi. Akurasi diukur dengan menggunakan confusion matrix. Confusion matrix akan menggambarkan hasil akurasi mulai dari prediksi positif yang benar, prediksi positif yang salah, prediksi negatif yang benar, dan prediksi negatif yang salah (Han & Kamber, 2007). Nilai akurasi dari model akan dibandingkan antara model yang terbentuk dengan algoritma neural network dan algoritma neural network yang sudah dioptimasi, serta pengujian terhadap algoritma windowed momentum.



Sumber: Hasil Penelitian (2015)

**Gambar 2. Model Pemikiran Penelitian**

Gambar 2 merupakan model pemikiran penelitian dimana data yang diperoleh dari UCI Machine Learning Repository tentang *Contraceptive method choice* pada *data processing* akan ditransformasi kedalam bentuk biner dalam fungsi aktivasi sigmoid, untuk dapat diproses kedalam algoritma Neural network untuk mendapatkan jaringan terbaik dari Neural network yang nantinya akan dilakukan proses feature selection dengan metode wrapper berupa Backward elimination dan pengujian algoritma menggunakan Windowed momentum. Hasil pengujian berupa *Confusion matrix*.

Dikarenakan fungsi aktivasi yang dipakai fungsi aktivasi sigmoid (biner), data harus ditransformasikan dulu karena batasan keluaran fungsi aktivasi sigmoid adalah [0,1], tapi akan lebih baik jika ditransformasikan ke interval yang lebih kecil, misal pada interval [0.1,0.9] (Siang, 2009). Maka, pada data pemilihan kontrasepsi yang ada dilakukan transform data dengan interval [0.1,0.9], dengan rumus sebagai berikut:

$$x^1 = \frac{0.8(x - a)}{b - a} + 0.1$$

Berikut perhitungan transform dengan menggunakan fungsi aktivasi sigmoid: Berdasarkan data pemilihan kontrasepsi pada atribut *Wife's age* diketahui

nilai minimum (a) = 16  
 nilai maximum (b) = 49


data kontrasepsi atribut *Wife's age* yang akan di transform  $x=24$

$$x^1 = \frac{0.8(24 - 16)}{49 - 16} + 0.1$$

$$x^1 = 0.294$$

Selanjutnya seluruh data ditransformasi dari bentuk tabel 1 menjadi tabel 2, maka didapat pola data pelatihan yang dipakai dalam bentuk aktivasi sigmoid.

Aktivasi sigmoid kemudian akan diolah dengan penggabungan antara algoritma neural network, backward elimination dan windowed momentum.



Sumber: Hasil Penelitian (2015)

**Gambar 3** Algoritma Penggabungan Neural Network, Backward Elimination, Windowed Momentum

Gambar 3 menggambarkan metode algoritma yang diusulkan dalam penelitian ini yaitu Neural Network berbasis backward elimination, Pada tahap preprocessing menggunakan algoritma Backward Elimination dengan memproses variabel input dan target dataset, setiap dihasilkan sebuah bagian maka akan diseleksi dengan algoritma Neural Network yang digunakan dan dibandingkan dengan bagian terbaik sebelumnya. Masalah utama yang ada pada Backpropagation adalah lamanya iterasi yang harus dilakukan. Backpropagation tidak dapat memberikan kepastian tentang seberapa epoch yang harus dilakukan untuk mencapai kondisi yang diinginkan, oleh karena itu parameter-parameter jaringan dibuat sehingga dihasilkan jumlah iterasi yang relatif lebih sedikit. Salah satu parameter yang paling berpengaruh adalah penentuan bobot yang ada didalam jaringan. Bobot yang menghasilkan nilai turunan aktivasi kecil sedapat mungkin dihindari karena akan menyebabkan perubahan bobot menjadi sangat kecil, demikian pula dengan nilai bobot awal yang terlalu besar karena akan menyebabkan nilai subset menjadi sangat kecil juga. Oleh karena itu dalam standar Backpropagation bobot dan bias diisi dengan bilangan acak kecil. Jika ditemukan subset terbaik maka itulah adalah subset terbaik saat ini, perulangan evaluasi akan berakhir sampai ditemukan subset terbaik dari hasil sebelumnya untuk meningkatkan performa pada backpropagation ini maka digunakanlah algoritma windowed momentum (Istook & Martinez, 2002).

Agar jaringan dapat belajar dengan baik maka dibuatlah pola pembelajaran sehingga jika dibandingkan dengan pola yang baru akan mudah dikenali. Beberapa metode untuk mengukur performa dari hasil suatu prediksi dalam bentuk perhitungan kesalahan. Perhitungan kesalahan merupakan pengukuran bagaimana jaringan dapat belajar dengan baik. Kesalahan pada keluaran jaringan merupakan selisih antara keluaran sebenarnya dan target atau disebut metode pembelajaran *Supervised learning* (Maimon & Rokach, 2010). Sedangkan RMSE adalah indikator kesalahan yang didasarkan pada total kuadrat dari simpangan antara hasil model dengan hasil observasi (kadhim& Abdulrazzaq, 2015).

**Tabel 1. Forecasts dan Error Measure**

Input	Wife's Age			
	FCST	Error	ABS error	SQ Err
24	32.53835709	8.538357094	8.538357094	72.90354187

Sumber: Hasil Penelitian (2015)

Tabel 1 menjelaskan tentang proses perhitungan untuk mencari nilai RMSE, dimana input merupakan data awal dari UCI Repository, FCST atau Forecast adalah nilai rata-rata dari keseluruhan atribut didalam Wife`s age, Error didapat dari pengurangan antara input dengan FCST, ABS error merupakan nilai Absolute dari error, SQ Err merupakan pangkat dari Error. Selanjutnya akan dicari nilai MAE, SSE, MSE dan RMSE.

Tabel 2 ditampilkan data Wife`s age dengan nilai minimum 16, maksimum 49, nilai rata-rata 32.53835709, nilai varian 67.68755627, standar deviation 8.227244755, STDEV 0.214364588, MAE 6.9652662, SSE 99636.08282, MSE 67.77964818 dan RMSE untuk Wife`s Age adalah 8.232839618.

**Tabel 2 Perhitungan RMSE**

Input	Min	Max	Mean	Varians	Standar deviation
wife`s age	16	49	32.538	67.68755	8.227244
<b>Std error of the mean (STD EV(Y) /SQRT(n))</b>	<b>Mean absolute error (MAE)</b>	<b>Sum of Squared Errors (SSE)</b>	<b>Mean Squared Error (SSE/(n-p))</b>	<b>RMSE (square root of MSE)</b>	
0.2143	6.9652	99636.08282	67.77964	8.232839	
64588	662	08282	818	618	

Sumber: Hasil Penelitian (2015)

**IV. HASIL DAN PEMBAHASAN**

Eksperimen yang dilakukan dengan penentuan beberapa parameter penunjang seperti training cycle, learning rate, momentum dan hidden layer perlu dilakukan untuk mendapatkan hasil yang lebih akurat.

Pengujian dilakukan dengan membagi data menjadi 50% data pelatihan berbanding 50% data pengujian, 60% data pelatihan berbanding 40% data pengujian, 70% data pelatihan berbanding 30% data pengujian, 90% data pelatihan berbanding 10% data pengujian agar didapatkan hasil yang maksimal dalam penentuan pemilihan metode kontrasepsi.

**Tabel 3. Data Pemilihan Kontrasepsi yang Digunakan**

wife`s age	wife`s education	husband`s education	number of children ever born	wife`s religion	wife`s now working?	husband`s occupation	standart-of-living index	media exposure	contraceptive method used
24	2	3	3	1	1	2	3	0	1

Sumber: Hasil Penelitian (2015)

**Tabel 4. Data Uji Pemilihan Kontrasepsi yang Digunakan**

wife`s age	wife`s education	husband`s education	number of children ever born	wife`s religion	wife`s now working?	husband`s occupation	standart-of-living index	media exposure	contraceptive method used
0.294	0.367	0.633	0.250	0.900	0.900	0.367	0.633	0.100	No Use

Sumber: Hasil Penelitian (2015)

**Tabel 5. Nilai Bobot Akhir Untuk Hidden Layer**

Node	Hidden Layer (Sigmoid)									
	A	B	C	D	E	F	G	H	I	Threshold
1	-16.156	-10.477	5.610	3.954	-0.320	1.080	5.941	-1.524	2.533	3.528
2	22.523	-5.592	-3.663	2.114	-3.487	3.810	1.246	-3.845	1.951	-11.304
3	3.464	-2.770	1.715	-30.618	-0.256	0.134	-0.478	-0.028	1.385	-25.012

Sumber: Hasil Penelitian (2015)

**Tabel 6. Nilai Bobot Akhir Untuk Output Layer**

CLASS	OUTPUT SIGMOID			THRESHOLD
	1	2	3	
No Use	0.401	2.334	4.487	-1.171
Long Term	-1.829	-1.226	-4.458	-0.321
Short Term	0.957	-1.879	-3.422	-0.481

Sumber: Hasil Penelitian (2015)

Tabel 3 menunjukkan data awal dari UCI Repository tentang *Contraceptive method choice* yang kemudian diubah ke bentuk aktivasi Tabel 4. dengan aktivasi sigmoid supaya data dapat diuji dan dilatih. Setelah data diubah menjadi bentuk aktivasi sigmoid maka akan didapat nilai untuk tiap bobot pada setiap node. Untuk output didapat nilai bobot sesuai dengan output layer yang ada seperti output untuk *No Use* pada hidden layer satu bernilai 0.401, pada hidden layer dua bernilai 2.334, pada hidden layer tiga 4.487 dengan nilai bias -1.171. Bobot untuk output *Long Term* pada hidden layer satu bernilai -1.829, pada hidden layer dua bernilai -1.226, pada hidden layer tiga -4.458 dengan nilai bias -0.321. Bobot untuk output *Short Term* pada hidden layer satu bernilai 0.957, pada hidden layer dua bernilai -1.879, pada hidden layer tiga -3.422 dengan nilai bias -0.481. Setelah semua nilai bobot diketahui maka akan diuji nilai akurasi pada data pemilihan metode kontrasepsi dengan menggunakan Rapidminer, berikut nilai akurasi terbaik yang didapat:

**Tabel 7. Nilai Akurasi Terbaik**

Trainin g Cycle	Learnin g Rate	Momentu m	Siz e	Akura si
500	0.3	0.2	3	54.37

Sumber: Hasil Penelitian (2015)

Nilai akurasi yang terbaik yang terbentuk adalah 54.37% dengan nilai *Training Cycle* 500, *Learning Rate* 0.3, *Momentum* 0.2 dan *Size* hidden layer sebanyak 3.

accuracy: 54.37% +/- 5.53% (mikro: 54.38%)				
	true no use	true long term	true short term	class precis
pred. no use	344	65	84	69.78%
pred. long term	80	118	88	41.26%
pred. short term	205	150	339	48.85%
class recall	54.69%	35.44%	66.34%	

Sumber: Hasil Penelitian (2015)

**Gambar 4 Hasil Akurasi Neural Network Pada RapidMiner**

Perhitungan Akurasi, Precision, Recall dan F-Measure sebagai berikut :

$$\text{Akurasi} = \frac{344 + 118 + 339}{344 + 65 + 84 + 88 + 118 + 80 + 205 + 150 + 339} = 0.5437 = 54.37\%$$

$$\text{Precision} = \frac{118}{80 + 118 + 88} = 0.412 = 41.2\%$$

$$\text{Recall} = \frac{118}{65 + 118 + 150} = 0.35435 = 35.435\%$$


$$\text{f-Measure} = \frac{2 * \text{recall} * \text{precision}}{(\text{recall} + \text{precision})} = \frac{2 * 0.35435 * 0.412}{0.35435 + 0.412} = 0.381 = 38.1\%$$

**Tabel 8. Eksperimen Untuk Menentukan Ukuran Hidden Layer Pada Hidden Layer 1 Neural Network**

Training Cycle	Learning Rate	Momentum	Size	Akurasi
500	0.3	0.2	1	45.62
500	0.3	0.2	2	47.18
<b>500</b>	<b>0.3</b>	<b>0.2</b>	<b>3</b>	<b>54.37</b>
500	0.3	0.2	4	53.69
500	0.3	0.2	5	53.90
500	0.3	0.2	6	53.83
500	0.3	0.2	7	53.09
500	0.3	0.2	8	53.02
500	0.3	0.2	9	53.49
500	0.3	0.2	10	52.68

Sumber: Hasil Penelitian (2015)

Setelah data diolah dengan beberapa parameter yang ada didapatkan hasil arsitektur jaringan yang dianggap terbaik yaitu dengan nilai akurasi yang paling besar, sebagai berikut:



Sumber: Hasil Penelitian (2015)

**Gambar 5** Arsitektur Jaringan yang didapat dari Hasil Eksperimen Neural Network

Arsitektur jaringan hasil eksperimen seperti yang terlihat pada gambar 5 dimana pada jaringan tersebut terdiri dari input layer dengan jumlah neuron 9, hidden layer dengan jumlah neuron 3, dan output layer dengan 3 neuron. Node bias (*threshold*) terdiri dari 2, yaitu terdiri dari 1 node bias pada input layer dan 1 node bias hidden layer. Inisialisasi bobot secara acak untuk input, hidden dan bias. Untuk setiap data pada data training pada tabel 1, dihitung input untuk simpul berdasarkan nilai input dan bobot jaringan saat itu, kemudian berdasarkan nilai input yang didapat untuk membangkitkan output untuk simpul dengan fungsi aktivasi. Hitung nilai error antara nilai yang diprediksi dengan nilai yang sesungguhnya. Selanjutnya backpropagated yaitu balik ke layer sebelumnya. untuk menghitung error pada hidden layer (hal ini untuk perbaharui bobot pada relasi). Hasil perhitungan akhir backpropagation fungsi aktivasi untuk simpul pada hidden layer terdapat pada tabel 3. Nilai akhir pada output layer dihitung menggunakan fungsi aktivasi linear terdapat pada tabel 4.


Eksperimen neural network berbasis backward elimination spesifikasi pada backward elimination yaitu pemilihan pada feature selection (*optimize selection*) dengan *selection direction* terdiri dari forward elimination dan backward elimination yang akan dipilih kemudian ditentukan *limit generation without improval* dan *generation without improval* sebanyak 1, tanpa disertai *limit number of generation* dan *keep best* sebanyak 1, dengan eksperimen sebagai berikut:

**Tabel 9.** Eksperimen Untuk Menentukan Ukuran Hidden Layer Pada Hidden Layer 1 Neural Network dengan Backward Elimination

Training Cycle	Learning Rate	Momentum	Size	Akurasi
500	0.3	0.2	1	50.04
500	0.3	0.2	2	51.73
<b>500</b>	<b>0.3</b>	<b>0.2</b>	<b>3</b>	<b>57.03</b>
500	0.3	0.2	4	55.87
500	0.3	0.2	5	56.35
500	0.3	0.2	6	55.47
500	0.3	0.2	7	55.81
500	0.3	0.2	8	55.20
500	0.3	0.2	9	55.80
500	0.3	0.2	10	55.60

Sumber: Hasil Penelitian (2015)

Hasil eksperimen untuk menentukan hasil akurasi terbesar pada hidden layer 1 penggabungan antara neural network dan backward elimination terdapat pada training cycle 500, learning rate 0.3, momentum 0.2, Hidden layer 3 dengan nilai akurasi 57.03%.




Sumber: Hasil Penelitian (2015)

**Gambar 6** Plot Nilai Bobot Setiap Atribut Pada Hidden Layer 1 ukuran 3

Pada gambar 6 menunjukkan, atribut yang dipakai setelah Neural Network berbasis backward Elimination di jalankan dengan hidden layer 1 dengan ukuran 3 maka, atribut yang terdapat pengurangan dimensi yaitu pada

Husband's Occupation dengan bobotnya adalah nol (0).

Implementasi dataset hasil Backward Elimination kedalam metode Neural Network, hal ini guna mendapatkan arsitektur jaringan yang terbaik. Setelah didapatkan arsitektur jaringan yang terbaik dari hasil eksperimen adalah sebagai berikut:



Sumber: Hasil Penelitian (2015)

**Gambar 7. Arsitektur Jaringan yang Didapat Dari Hasil Eksperimen Neural Network Dengan Backward Elimination**

Berdasarkan gambar 7, model yang didapat adalah model dengan pola 8-3-3 dengan akurasi 57.03%. Hasil eksperimen yang telah dilakukan dengan metode Neural Network dan metode Neural Network berbasis Backward Elimination maka didapatkan hasil sebagai berikut:

**Tabel 10. Perbandingan Akurasi**

Meth od	Train ing Cycl e	Learn ing Rate	Momen tum	Hid den Lay er	Si ze	Akur asi
NN+ BE	500	0.3	0.2	1	3	57.0 3%
NN	500	0.3	0.2	1	3	54.3 7%

Sumber: Hasil Penelitian (2015)

Berdasarkan tabel 10, Hasil penelitian menunjukkan metode jaringan syaraf tiruan berbasis backward elimination menghasilkan peningkatan akurasi 2.66% dibandingkan hanya dengan menggunakan metode jaringan syaraf tiruan saja. Akurasi yang dihasilkan dengan metode Neural Network berbasis Backward Elimination dapat meningkatkan

hasil akurasi lebih tinggi yaitu 57.03% jika dibandingkan dengan Akurasi yang dihasilkan dengan metode Neural Network yaitu 54.37%. Hal ini menunjukkan bahwa prediksi pemilihan kontrasepsi dengan menggunakan Neural Network berbasis Backward Elimination lebih akurat.

Pada algoritma windowed momentum membutuhkan perhitungan dari bobot sebelumnya, untuk mendapatkan  $\Delta w_x$  (Istook & Martinez, 2002). beberapa langkah yang harus dilakukan yaitu : Hitung keluaran unit  $Y_k$ , Hitung faktor  $\delta$  di unit keluaran  $Y_k$ , Hitung penjumlahan kesalahan dari hidden layer, Hitung semua perubahan bobot.

Berikut perhitungan untuk standar

momentum

No Use

$$\Delta wt = \sum_x^T \frac{\Delta wx}{|T|}$$

Long Term

Perhitungan untuk Windowed Momentum

Short Term

$$\Delta wt = \sum_x^s \frac{\Delta wx}{|S|}$$


**Tabel 11. Perbandingan Momentum**

Method	No Use	Long Term	Short Term
Standar Momentum	0.672302	-	-
Windowed Momentum	0.75634	-	-0.6028

Sumber: Hasil Penelitian (2015)

Berdasarkan tabel 11 terlihat bahwa peningkatan backpropagation pada neural network berbasis Backward elimination dapat ditingkatkan dengan algoritma windowed momentum pada pemilihan metode kontrasepsi baik yang tidak menggunakan metode kontrasepsi, metode kontrasepsi jangka panjang maupun metode kontrasepsi jangka pendek.

Selanjutnya akan dibuat perancangan perangkat lunak dalam penelitian ini yang berdasarkan hasil terbaik yang telah terbentuk dengan perbandingan antara Windowed momentum dan Standar momentum.



Sumber: Hasil Penelitian (2015)

**Gambar 8. Perancangan Perangkat Lunak**

Perancangan perangkat lunak yang telah dibuat harus dilakukan pengujian agar mencapai standar kualitas perangkat lunak yang baik. Menurut (Alrawashdeh dkk, 2013) faktor kualitas ditentukan dari karakteristik perilaku sistem. Untuk itu diperlukan penilaian perancangan perangkat lunak dari pemegang kepentingan dan pengguna akhir. Menurut ISO 9126, karakter-karakter yang menggunakan kualitas suatu perangkat lunak ditentukan oleh *portability, functionality, Reliability, Usability, efficiency dan maintainability*.

## V. PENUTUP

Penelitian ini dilakukan pengujian model dengan menggunakan neural network dan neural network dengan feature selection berupa metode Wrapper dengan penyeleksian berupa Backward Elimination serta penggunaan algoritma windowed momentum untuk membuktikan performa momentum yang ada didalam algoritma Backpropagation dengan menggunakan data dari UCI yaitu *Contraceptive Method Choice*.

Pada penelitian ini secara umum penerapan model NN dan BE serta Windowed momentum dapat meningkatkan akurasi prediksi pemilihan metode kontrasepsi, akan tetapi karena keterbatasan penelitian ini perlu disarankan untuk melakukan penelitian lanjutan yang berkaitan dengan prediksi untuk mendapatkan akurasi yang lebih baik. Adapun yang perlu diberikan yaitu:

1. Perlu dilakukan penelitian lanjutan dengan penambahan fitur yang lain seperti lokasi atau suku.
2. Perlu dilakukan penelitian yang sejenis dengan variasi proses model misalnya dengan penambahan Cross validation.
3. Perlu dilakukan penelitian yang sejenis dengan variasi metode seleksi dalam pengklasifikasian misalnya feature selection dengan metode embedded atau filter sehingga dapat digunakan untuk perbandingan dari hasil penelitian ini.

## DAFTAR PUSTAKA

- Alpaydin, Ethem. (2010). *Introduction to Machine Learning*. The MIT Press, London UK.
- Alrawashdeh, Thamer A, & Muhairat, Mohammad, Ahmad Althunibat,. (2013). Evaluating the Quality of Software in ERP. Department of software Engineering, Alzaytoonah University of Jordan, Amman, Jordan.
- Asliyan, Rifat. (2011). *Syllable Based Speech Recognition*. Computer and Information Science. Diambil dari: <http://www.intechopen.com/books/speech-technologies/syllable-based-speech-recognition>. (3 Desember 2014).
- Bandyopadhyay, G & Chattopadhyay. (2008). *An Artificial Neural Net Approach to Forecast The Population of India*. India.
- BKKBN. Nd. Cara-Cara Kontrasepsi yang Digunakan Dewasa Ini. Diambil dari: <http://www.bkkbn-jatim.go.id/bkkbn-jatim/html/cara.htm>. (3 Desember 2014).
- Badan Pusat Statistik. nd. Laju Pertumbuhan Penduduk Menurut Provinsi. Diambil dari: [http://bps.go.id/tab\\_sub/view.php?tabel=1&daftar=1&id\\_subyek=12&notab=2](http://bps.go.id/tab_sub/view.php?tabel=1&daftar=1&id_subyek=12&notab=2). (3 November 2014).
- Chaurasia, Aalok Ranjan. (2014). *Contraceptive Use In India: A Data Mining Approach*. Shyam Institute, India.
- Ciampi, Antonio. Zhang, Fulin. (2002). *A New Approach to Training Backpropagation Artificial Neural Network: Empirical Evaluation on Tens Dataset on Clinical Studies*. McGill University. Canada.
- Gorunescu, Florin. (2011). *Data Mining: Concepts, Models and Techniques*. Verlag Berlin Heidelberg, Springer. Jerman.
- Guillet, Fabrice. Hamilton, Howard J. (2007). *Quality Measures in Data Mining*. Verlag Berlin Heidelberg, Springer. Jerman.
- Han,J & Kamber, Micheline. (2007). *Data Mining Concepts, Models and Techniques*. Second Edition, Morgan Kaufmann Publisher. Elsevier.
- Hagiwara, Masafumi.(1992). *Theoretical Derivation of Momentum Term in*

- Back-Propagation.* International Joint Conference on Neural Networks. IEEE. pp682-686.
- Heaton, Jeff. (2010). *Programming Neural Networks With Encog 2 In Java.* Heaton Research.Inc, USA.
- Hong, X., Harris, C., Brown, M., & Chen, S. (2002). *Backward Elimination Methods for Associative Memory Network Pruning.* Computers and Technology, (Reed 1993).
- Istook, Erneez & Martinez, Tony (2002). Improved backpropagation learning in neural networks with windowed momentum. Computer Science Department. Brigham Young University, pp. 303-318.
- Kadhim, Jehan & Abdulrazzaq, Mohammad (2015). Forecasting USD/IQD Future Values According to Minimum RMSE Rate. Thi\_Qar University. pg.271–285
- Kohavi, R., & John, H. (1997). *Artificial Intelligence Wrappers for feature subset selection.* *elsevier*, 97(97), 273–324.
- Kusumadewi, Sri & Hartati, Sri. (2010). *Neuro-Fuzzy Integrasi Sistem Fuzzy & Jaringan Syaraf.* Second Edition. Yogyakarta: Graha Ilmu.
- Larose, D. (2005). *Discovering Knowledge in Data.* New Jersey, John Willey & Sons.Inc.
- Liao, Warren. T. & Triantaphyllou. Evangelos. (2007). *Recent Advances in Data Mining of Enterprise Data: Algorithms and Applications.* Series: Computer and Operation Research. 6. 190.
- Lim TS, Loh WY, Shih YS. (1999). A comparison of prediction accuracy, complexity, and training time of thirty-three old and new classification algorithms. Kluwer Academic Publishers: Boston.
- Liu, Huan, Yu, Lei.(2005). *Toward Integrating Feature Selection Algorithms for Classification and Clustering.* Department of Computer Science and Engineering. Arizona State University.
- Liu, Yuaning, Wang G., Chen, M., Dong, M., Zhu, X., Wang, S. (2011). *An Improved Particle Swarm Optimization for Feature Selection.* College of Computer Science and Technology. China.
- Maimon, Oded & Rokach, Lior. (2010). *Data Mining and Knowledge Discovery Handbook,* Springer, New York.
- Myatt, Glenn J. (2007). *Making sense of data : A Practical Guide to Exploratory data analysis and Data Mining.* John Wiley & Sons Inc, New Jersey.
- Shukla, Anupam. Tiwari, Ritu. & Kala, Rahul. (2010). *Real Life Application of Soft Computing.* New York: Taylor and Francis Groups, LLC.
- Siang, Jong Jek (2009). *Jaringan Syaraf Tiruan dan Pemrogramannya menggunakan MATLAB.* Penerbit Andi. Yogyakarta.
- Vercellis,C. (2009). *Business Intelligence: Data Mining and Optimization for Decision Making.* Wiley.
- Witten,I. Frank, E., & Hall. (2011). *Data Mining: Practical Machine Learning and tools.* Morgan Kaufmann Publisher, Burlington.